

CAMBIO CLIMÁTICO Y PRODUCTIVIDAD DE TRIGO EN ESPAÑA

Sara HERNÁNDEZ-BARRERA¹, Concepción RODRÍGUEZ-PUEBLA¹

¹*Depto. de Física General y de la atmosfera. Universidad de Salamanca*

sarahb@usal.es concha@usal.es

RESUMEN

Para caracterizar los impactos y tomar medidas de adaptación en otras condiciones climáticas las proyecciones de producciones agrícolas aportarían información de gran utilidad. En este trabajo se muestra un ejemplo de estudio de los cambios de la productividad del trigo en el siglo XXI usando modelos CMIP5. El desarrollo del trabajo requiere diferentes etapas: en la primera se analizan las relaciones entre datos de producción de trigo y diferentes variables climáticas para el periodo observacional. Para el estudio regional hemos obtenido que las variables climáticas que influyen en la productividad del trigo son la precipitación acumulada en marzo, el rango diurno de temperatura en diciembre y el índice de aridez en mayo. Sin embargo las teleconexiones que se presentan entre las variables climáticas regionales y a gran escala justifica la influencia de la temperatura superficial del mar en el Pacífico Tropical en diciembre y el viento a nivel de 250hPa en el área del Atlántico Norte en mayo. En una segunda etapa se obtienen modelos empírico estadísticos para representar la evolución de la producción de trigo considerando las diferentes variables climáticas. En la tercera etapa se aplican los modelos para proyectar los cambios de la productividad del trigo en el clima futuro. Dentro de las novedades del trabajo destacamos el método usado para filtrar la tendencia no lineal de la productividad de trigo mediante descomposición empírica en modos de variación y el método de regresión por mínimos cuadrados parciales para obtener los modelos empírico estadísticos.

Palabras claves: Productividad del trigo; Precipitación; Temperatura; Aridez; Viento en altura; Temperatura superficial del mar; Península Ibérica.

ABSTRACT

Agricultural production projections under other climate conditions are of great interest for impact and adaptations characterizations. In this study we analyse changes of wheat productivity in the 21st century using CMIP5 models. The study is performed in different steps: In the first part we obtained relationships between wheat productivity and different climate variables for the observational period. We found the following climate variables affecting wheat productivity: accumulated precipitation in March, diurnal range of temperature in December and aridity index in May. Since there are relationships between regional and large-scale climate variables it is found that Sea Surface Temperature over Tropical Pacific and zonal wind at 250 hPa level over North Atlantic are related to the variability of wheat productivity. Therefore, in a second step we provide empirical models to characterize wheat productivity evolution as a function of different climate variables. In the third step the models are applied to project the changes in future climates. Regarding the methodology we applied Empirical Mode Decomposition to filter the no linear trend of

the wheat productivity and Partial Least Square regression to extract the dominant climate modes that account for variations of wheat productivity.

Key words: Wheat productivity; Precipitation; Temperature; Aridity; Zonal Wind; Sea Surface Temperature; Iberian Peninsula.

1. INTRODUCCION

El cambio climático es uno de los principales problemas para la agricultura en el siglo XXI debido a las alteraciones producidas en las temperaturas y las precipitaciones. Estos factores climáticos son importantes para la productividad agrícola. En la Península Ibérica, el clima presenta grandes variaciones y a partir de 1970 las temperaturas máximas han aumentado (Moreno, 2005) y las precipitaciones en algunos meses parece que tienden a disminuir como en febrero y marzo (Bladé y Castro, 2011). Estos cambios pueden afectar a las series temporales de las producciones agrícolas, y justificarían en gran medida su variabilidad interanual.

El número de eventos extremos (sequías, olas de calor, inundaciones, etc.) parece que tiende a incrementarse en las últimas décadas y ello repercute de manera importante en la agricultura. Las dificultades que presentan los modelos agrícolas para caracterizar la evolución de las producciones (Landau *et al.*, 1998) hace que se impulsen otros métodos de carácter estadístico para analizar los datos históricos de producciones agrícolas junto con los climáticos. Según las aplicaciones se desarrollan tanto estudios que modelizan producciones considerando los efectos del clima en el ciclo vegetativo de las plantas (Song *et al.*, 2006; Adejuwon, 2006; Cantelaube & Terres, 2005) como otros estadísticos centrados en explicar la variabilidad de producciones por los efectos del clima (Kucharick and Serbin, 2008; Lobell *et al.*, 2008; Tao *et al.*, 2008; You *et al.*, 2009; Zhang and Huang, 2012). En España, la evaluación de los efectos climáticos en las producciones agrícolas ha sido solo estudiada principalmente en regiones puntuales. Por ejemplo, Vicente-Serrano *et al.* (2006) utilizaron los índices de sequías y los datos de teledetección para predecir la producción del trigo y de la cebada en el valle del Ebro. Iglesias y Quiroja (2007) estudiaron el riesgo de la variabilidad climática sobre las producciones de cereales en 5 zonas de España. Blanco-Ward *et al.* (2007) analizaron la variabilidad climática espacial sobre la viticultura en el valle del río Miño, en Galicia.

Rodríguez-Puebla *et al.* (2007) estudiaron la relación de las variaciones de cereales de invierno con variables climáticas. Actualmente, mediante la aplicación de métodos más específicos podemos ampliar estos estudios para obtener modelos empíricos que describan y justifiquen las relaciones entre las variables climáticas y la productividad del trigo en España. Así como para aplicarlos con modelos del Panel Intergubernamental del Cambio Climático (IPCC) or Coupled Model Intercomparison Project, phase 5 (CMIP5). Para desarrollar el estudio se han utilizado variables climáticas a escala regional y a gran escala.

El trabajo se organiza de la siguiente manera: en la sección de datos se describen los datos utilizados en este estudio y el procedimiento llevado a cabo para eliminar la tendencia no lineal de las series temporales. En la sección de metodología se desarrollan las diferentes técnicas estadísticas aplicadas para obtener los modos climáticos, que mejor explican la variabilidad del trigo, y las relaciones entre las variables climáticas y la productividad del trigo. En la sección de resultados se analiza los modelos que describen la influencia de las variables climáticas que influyen en la variabilidad de la producción del trigo así como los cambios en la producción del trigo en el clima futuro.

2. DATOS

Los datos que se han utilizado en el desarrollo de este estudio son: datos históricos de la productividad del trigo de España, proporcionados por el Ministerio de Agricultura, Alimentación y Medio Ambiente (<http://www.magrama.gob.es>); colección de datos E-OBS del proyecto EU-FP6 ENSEMBLES (Haylock *et al.*, 2008, <http://ensembles-eu.metoffice.com>); datos de presión al nivel del mar, viento a nivel de 250hPa del proyecto de reanálisis NCEP/NCAR (National Centers for Environmental Prediction/National Centers for Atmospheric Research) (Kalnay *et al.*, 1996, <http://www.cdc.noaa.gov/cdc/data.ncep.reanalysis.html/>); datos de la temperatura superficial del mar del proyecto ERSST v3b (Smith *et al.*, 2008, <http://www.ncdc.noaa.gov/ersst/>); datos históricos y experimentales del modelo HadGEM2-CC que se enmarcan en la quinta fase del proyecto internacional de inter-comparación de modelos WCRP CMIP5 (Martin *et al.*, 2011, <http://pcmdi9.llnl.gov/esgf-web-fe/>).

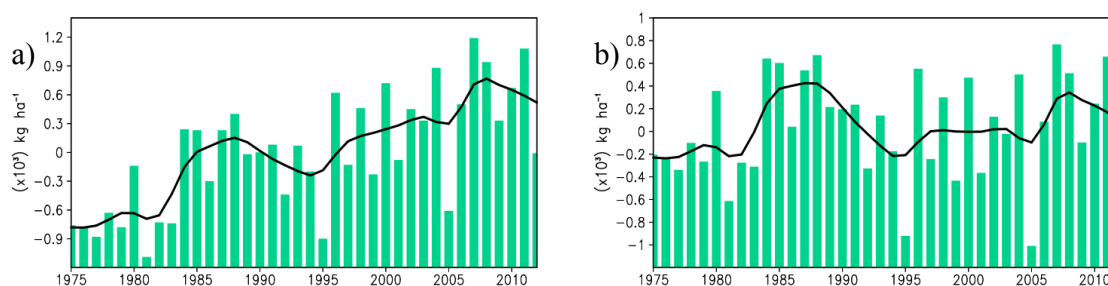


Fig. 1: Evolución temporal de la productividad del trigo en España (barras) y su media móvil (línea): a) serie total y b) serie estandarizada y sin la tendencia no lineal.

En la Figura 1a se muestra la serie histórica de la productividad del trigo para el período 1975-2012. Podemos observar un aumento de la productividad del trigo a lo largo de este período, este aumento se puede deber a la mejora de las técnicas agrícolas. Por este motivo, eliminamos la tendencia creciente observada aplicando el método de descomposición empírica en modos (Huang *et al.*, 1998) (Figura 1b).

Examinando los tres años con menor productividad de (1981, 1995, 2005), estos han sido referenciados como muy secos por Vicente-Serrano *et al.* (2014). En el trabajo comprobaremos la influencia de la precipitación, temperatura y aridez.

3. METODOLOGÍA

3.1. Descomposición empírica en modos

El primer problema con que nos encontramos al observar la serie de productividad es la tendencia, esta señal puede enmascarar la identificación de las relaciones entre la variabilidad climática y las producciones. Por ello es necesario filtrar esta componente. El factor que probablemente ejerza mayor influencia en la tendencia sería el desarrollo tecnológico. Para filtrar la influencia de esta tendencia incorporamos en el estudio un método empírico de descomposición de series temporales en modos de variación o “Empirical Mode Decomposition” (EMD) (Huang *et al.*, 1998) es un método adaptativo para el análisis de

datos no lineales y no estacionarios. El método EMD descompone una señal en un número finito de funciones de modo intrínseco (IMFs), estas funciones son dependientes de la señal y con ellas se puede reconstruir la señal original. Para ser considerada una IMF debe satisfacer dos condiciones: la cantidad de puntos extremos (máximos y mínimos) y la cantidad de cruces por cero deben de ser iguales o diferir lo sumo en uno; la media local, definida como el valor medio de las envolventes superior e inferior, debe ser nula para todo punto.

Si la primera IMF no cumple dichas condiciones, se repetirá el mismo procedimiento hasta que se cumplan. Al terminar el proceso, la señal se puede expresar de la siguiente manera:

$$s(t) = \sum_{i=1}^k I_i(t) + d_k(t)$$

donde $I_i(t)$ son las diferentes funciones de modo intrínseco, k es el número de IMFs y $d_k(t)$ es el residuo. Este residuo corresponde con la tendencia no lineal de nuestra serie temporal. Por lo tanto, la serie temporal de la productividad del trigo sin tendencia será la suma de todas las IMFs excepto la última.




Fig. 2: Funciones intrínsecas (IMFs) y tendencia no lineal para la serie histórica de la productividad del trigo en España.

La Figura 2 muestra la tendencia no lineal y todas las IMFs en las que se descompone la serie al aplicar el método EMD.

3.2. Regresión de mínimos cuadrados parciales.

La regresión de mínimos cuadrados parciales (PLS) puede analizar datos altamente correlacionados y que contienen ruido y numerosas variables (Wold *et al.*, 2001). Este método modeliza la relación existente entre dos conjuntos de variables observadas para obtener nuevas variables denominadas variables latentes.

El PLS utiliza como datos de entrada dos matrices: X e Y , X son las variables predictoras o independientes e Y son las variables predictando o dependientes. Este método de regresión aprovecha la alta correlación que existe entre las variables independientes para sustituirlas por unas nuevas variables que no están correlacionadas entre sí, estas variables se denominan variables latentes. Las variables latentes se obtienen mediante la combinación lineal de las variables independientes siendo ortogonales, con lo cual no contienen información redundante (Rosipal, 2006) pero a su vez incluyen la máxima covarianza con las variables dependientes.

El objetivo del PLS es eliminar la información redundante, para ello busca la máxima variabilidad en la matriz X y la mayor correlación con la matriz Y , eliminando la

multicolinealidad, y maximizando la covarianza, lo que nos indica que no se pierde información.

Con esta metodología obtenemos las relaciones entre las variables climáticas y la productividad de trigo. Las variables climáticas, tanto a escala regional como a gran escala, son los predictores y la productividad del trigo sin tendencia en España el predictando. La finalidad, al aplicar este método, es obtener las variables latentes como combinación lineal de los datos climáticos que maximizan la varianza de la productividad del trigo.

El método PLS se aplica para obtener los modelos regionales y a gran escala. Es decir, se utiliza con datos E-OBS, los de reanálisis y los de temperatura superficial del mar (SST). Para obtener las series temporales y la estructura de diferentes campos climáticos que están asociados a la productividad del trigo. A partir de las series temporales obtenemos la simulación de la productividad del trigo para el período observado (1975-2012), y la estructura espacial nos permite obtener la simulación de la productividad del trigo en climas futuros a partir de los datos CMIP5.

3.3. Regresión lineal múltiple.

El análisis de regresión lineal múltiple se aplica para obtener el modelo que describe la evolución de la productividad de trigo en función de las variables que proporciona el método PLS. El procedimiento seguido es el de paso a paso para evitar “overfitting” con el fin de seleccionar entre todas las variables independientes aquellas que mejor expliquen la variable dependiente sin que ninguna de ellas sea combinación lineal de las restantes (Field, 2005).

La regresión lineal múltiple nos permite seleccionar y combinar las variables climáticas latentes derivadas del PLS para obtener el modelo de simulación empírico del trigo. Con los coeficientes de la regresión podemos derivar los cambios en las proyecciones del trigo utilizando los modelos CMIP5.

4. RESULTADOS

Las variables de partida son la precipitación acumulada, las temperaturas media, máxima y mínima mensual en escala regional, a gran escala son la presión al nivel del mar, el viento zonal a 250 hPa y la temperatura superficial del mar. Además a partir de las variables regionales se obtienen los índices derivados de aridez o Gaussen y el rango de temperatura o la diferencia entre temperatura máxima y mínima. Con la base de datos de las diferentes variables para toda la península y los diferentes meses se procede al análisis con el fin de identificar las variables y los meses que se asocian con la producción de trigo. Una vez realizada la reducción de variables mediante el procedimiento PLS se obtuvo el modelo lineal para representar la evolución de trigo. Las variables climáticas seleccionadas en el análisis de regresión lineal múltiple son: la precipitación acumulada (rr) en marzo, el rango diurno de temperatura (dtr) en diciembre y el índice de aridez o de Gaussen en mayo. El índice de Gaussen (GI) combina los efectos de temperatura y precipitación. Este índice se define como $(2T(^{\circ}\text{C}) - \text{rr}(\text{mm/mes}))$ y se estandariza utilizando el procedimiento aplicado para el índice estandarizado de precipitación (SPI), el significado de la ecuación es comparar la precipitación con un valor de referencia que equivale al doble de la temperatura. Por otro lado, hemos considerado variables climáticas a gran escala; la presión al nivel del mar (SLP), la temperatura superficial del mar (SST) y el viento a nivel de 250hPa (U250hPa). El método de regresión lineal múltiple seleccionó U250hPa en el área del Atlántico Norte en mayo y la

SST en el Pacífico tropical en diciembre como variables influyentes en la productividad del trigo.

Las figuras 3a, 3b y 3c muestran la configuración espacial, derivadas del método PLS, de la precipitación acumulada en marzo, el rango diurno de temperatura en diciembre y el índice de aridez de mayo. La correlación entre el cultivo y el dtr es negativa, al igual que el índice de aridez. Pero para la precipitación es positiva. Estas asociaciones se justifican por las condiciones óptimas requeridas por el ciclo vegetativo del trigo de octubre a principios de junio. Las precipitaciones abundantes deben darse en la época de crecimiento del grano, principalmente en primavera, sin embargo en el invierno temperaturas muy extremas no favorecen la producción. La siega se realiza cuando la humedad es muy baja y las temperaturas han secado la planta para que la semilla se conserve.

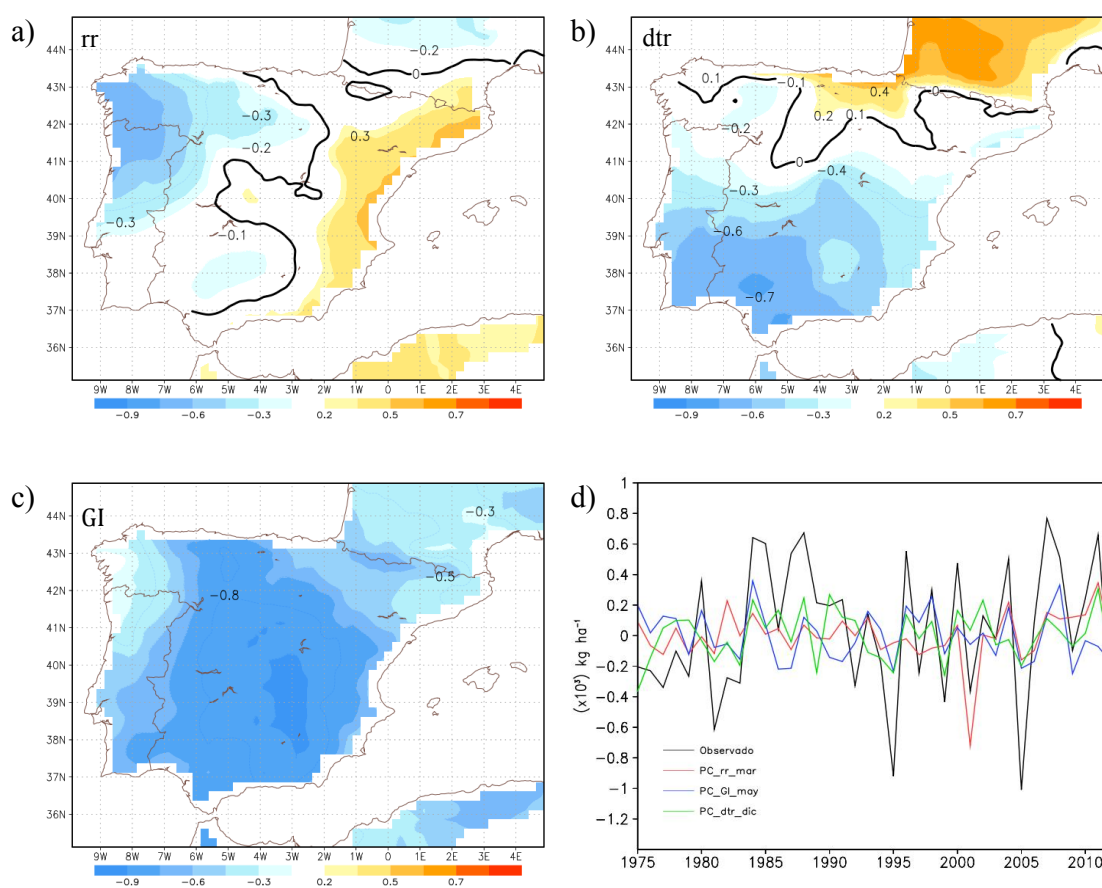


Fig. 3: Configuración espacial (a,b,c) y series temporales (d) derivadas del método PLS y las anomalías del trigo observadas para las variables a escala regional (Precipitación acumulada (rr) en el mes de marzo, Rango diurno de temperatura (dtr) en el mes de diciembre e Índice de aridez (GI) en el mes de mayo).

Las figuras 4a y 4b muestran la configuración espacial derivada del PLS para las variables a gran escala, para la SST en diciembre y para U250hPa en mayo. La intensidad de la corriente en chorro subtropical y subpolar favorece la producción de trigo. La corriente en chorro tiene mayor efecto en la productividad de trigo en mayo, lo cual concuerda con que en dicho mes la relación con la aridez es muy significativa y opuesta. Sin embargo, anomalías negativas de SST en el Pacífico tropical está asociado con la producción, lo que indica que para años de El

Niño la productividad del trigo disminuye. En un estudio previo (Rodríguez-Puebla et al. 2007) se identificó la influencia del ENSO en la producción de cereal de invierno. Asimismo diferentes estudios han mostrado la relación entre el fenómeno El Niño con la precipitación en la PI, en particular produce disminución de la precipitación en primavera (Esteban-Parra *et al.*, 1998; Rodo *et al.*, 1997).

Las figuras 3d y 4c muestran las series temporales derivadas del PLS de las variables que influyen en la producción de trigo en escalas regional y a gran escala junto con las anomalías del trigo observadas. En la tabla 1 se pueden observar las correlaciones entre las variables y la productividad del trigo.

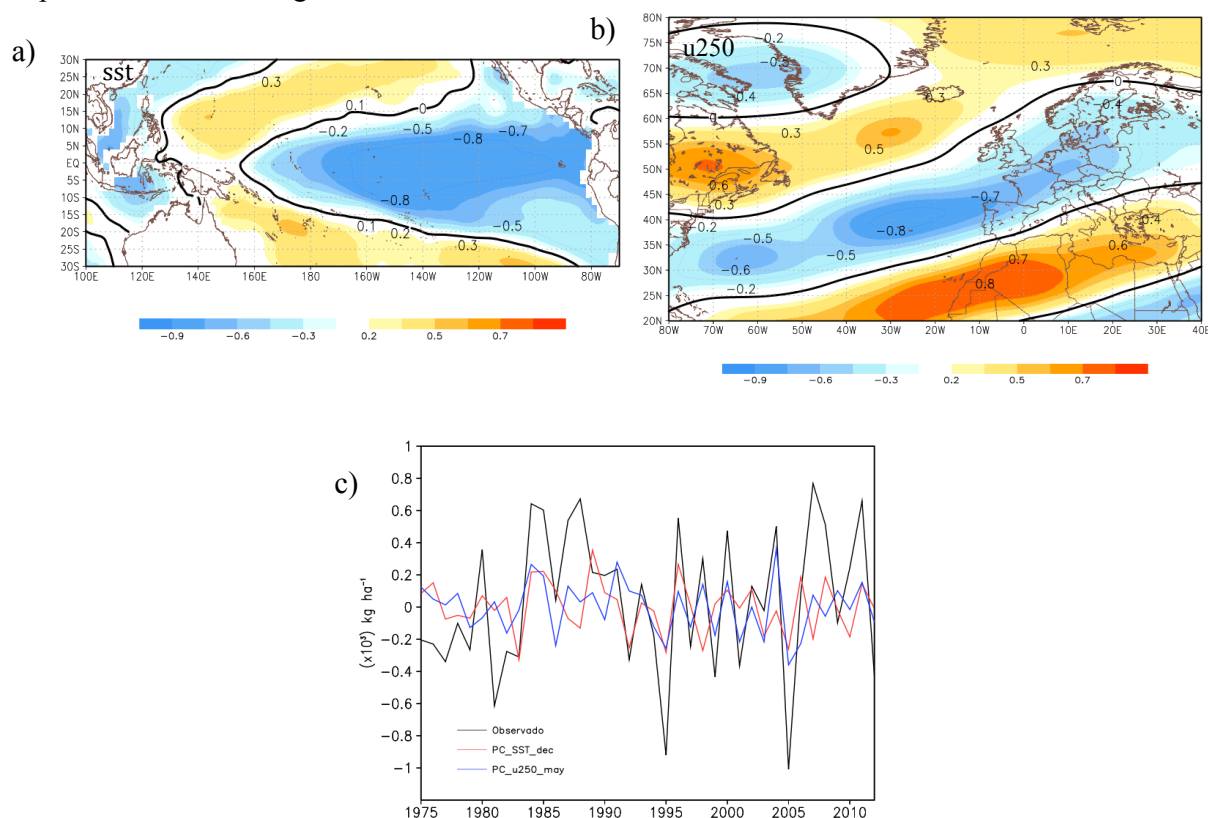


Fig. 4: Configuración espacial (a,b) y series temporales (c) derivadas del método PLS y las anomalías del trigo observadas para las variables a gran escala (SST en el Pacífico Tropical en el mes de diciembre y U250hPa en el área del Atlántico Norte en el mes de mayo).

Correlaciones entre la productividad del trigo y los modos de las variables climáticas			
Escala regional		Gran escala	
rr	0.466±0.007	SST	0.547±0.006
dtr	0.611±0.009	U250hPa	0.626±0.009
GI	0.511±0.007		

Tabla 1: CORRELACIONES ENTRE LA PRODUCTIVIDAD DEL TRIGO Y LOS MODOS (PCS) DE LAS VARIABLES CLIMÁTICAS (RR EN MARZO, DTR EN DICIEMBRE, GI EN MAYO, SST EN DICIEMBRE Y U250HPA EN MAYO).

Una vez seleccionadas las variables climáticas que afectan a la productividad del trigo, obtenemos el modelo que simula la productividad del trigo en función de las variables seleccionadas. Los modelos que reconstruyen la variabilidad del trigo, tanto a escala regional como a gran escala, se muestran en las figuras 5a, 5b respectivamente junto con el intervalo de confianza del modelo en sombreado. Estos modelos se ajustan adecuadamente con las anomalías del trigo observadas, presentando altas correlaciones entre ellos.

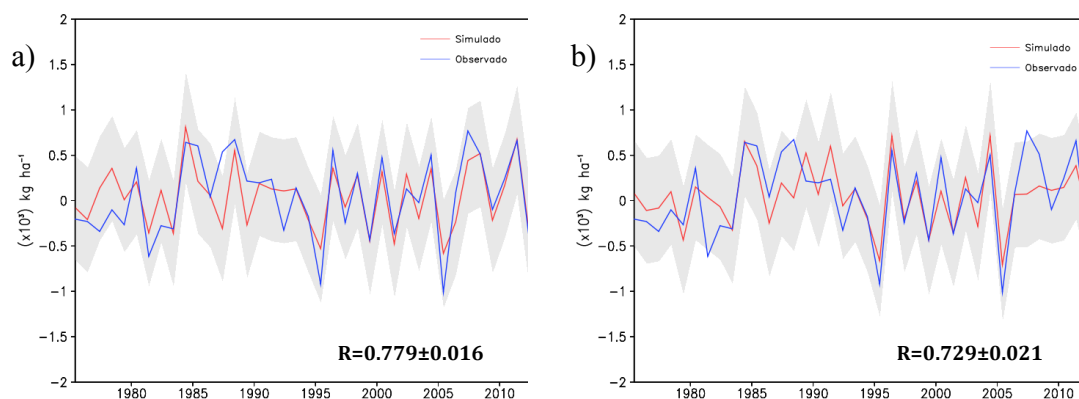


Fig. 5: Series temporales de las anomalías del trigo observadas y simuladas y el intervalo de confianza (sombreado): a) a escala regional y b) a gran escala.

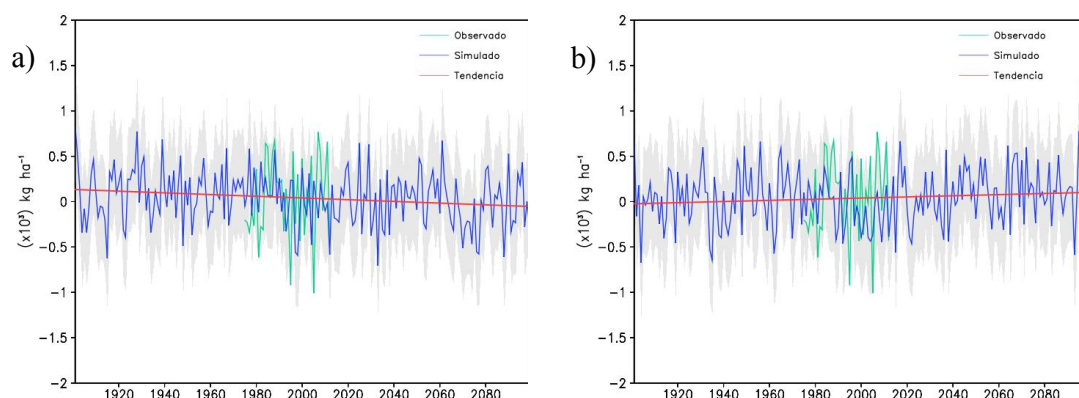


Fig. 6: Series temporales de las anomalías del trigo observadas y simuladas derivadas del modelo HadGEM2-CC y el intervalo de confianza (sombreado) usando: a) variables a escala regional y b) variables a gran escala.

Una de las principales aplicaciones del estudio es poder informar sobre el cambio de productividad en climas más cálidos. Para ello consideramos los datos climáticos de un modelo CMIP5. Para este trabajo se consideró el modelo HADGEM2-C (Martin *et al.*, 2011). Con los diferentes datos de temperatura máxima, mínima, precipitación, temperatura superficial del mar y viento y mediante las configuraciones espaciales relacionadas con la productividad de cereal se derivaron los índices futuros que influyen en el cultivo. Con estos índices y el modelo empírico se elaboraron las proyecciones de la productividad del trigo para el clima futuro. Para el modelo a escala regional se ha utilizado la precipitación acumulada, el rango diurno de temperatura y índice de aridez (Figura 6a). Y para el modelo a gran escala se han utilizado las variables de la SST y el U250hPa (Figura 6b). En el modelo a escala regional se puede observar que la productividad del trigo disminuirá durante el período

2013-2100, siendo la tendencia aproximada de -0.20×10^3 kg/ha. En el modelo a gran escala no se observan cambios significativos en la productividad, una ligera tendencia de aumento de 0.12×10^3 kg/ha. Una preliminar interpretación de estas diferencias puede ser a que los modelos muestran fallos en representar la tendencia de la circulación (Gillett y Fyfe, 2013).

5. CONCLUSIONES

En este trabajo hemos analizado los factores climáticos que afectan a la productividad del trigo en España. Los procedimientos aplicados son la regresión por mínimos cuadrados parciales y la regresión lineal múltiple. Los modelos empíricos estadísticos obtenidos muestran un buen acuerdo entre las variables climáticas y la productividad del trigo.

A partir de los resultados obtenidos podemos destacar: los meses más influyentes para la productividad del trigo son marzo (rr), mayo (GI, U250hPa) y diciembre (dtr, SST); para las variables a escala regional, la asociación de la productividad con la precipitación es positiva y para las variables GI y dtr es negativa; en el caso de las variables a gran escala, se encuentran anomalías negativas con la SST sobre el Pacífico Tropical y con U250hPa existe una fuerte asociación con la intensidad de las corrientes en chorro subtropicales y subpolares.

Los modelos empíricos regionales que simulan la productividad del trigo para el clima futuro muestran una tendencia decreciente para el período 2013-2100, lo que indica una disminución de las producciones del trigo. En cambio, los modelos a gran escala no presentan tendencias significativas.

Estos resultados serán ampliados con estudios que consideren otros modelos y para otros cultivos de interés para España.

6. AGRADECIMIENTOS

Este estudio se ha realizado en el marco del proyecto CGL2011-23209, financiado por el Ministerio de Economía y Competitividad de España y gracias al proyecto SA222A11-2 de la Junta de Castilla y León. Queremos dar nuestro agradecimiento a el proyecto EU-FP6 ENSEMBLES y al proyecto internacional de inter-comparación de modelos WCRP CMIP5 por los datos suministrados. Y a los desarrolladores de los software GrADS, CDO y R.

7. BIBLIOGRAFÍA

- Adejuwon, J.O. (2006). *Food crop production in Nigeria. II. Potential effects of climate change*. Clim Res 32:229–245.
- Bladé, I. y Castro-Díez, Y. (2010). *Tendencias atmosféricas en la Península Ibérica durante el periodo instrumental en el contexto de la variabilidad natural*. En F. Pérez & R. Boscolo, (Eds). Clima en España: pasado, presente y futuro. 25-42 pp.
- Blanca-Ward, D.; Garcia-Queijeiro, J.M. y Jones, G.V. (2007). *Spatial climate variability and viticulture in the Miño River Valley of Spain*. Vitis 46 (2), 63-70.
- Cantelaube, P. y Terres, J.M. (2005). *Seasonal weather forecasts for crop yield modeling in Europe*. Tellus Ser A Dyn Meteorol Oceanogr 57:476–487.
- Corte-Real, J.; Qian, B.D. y Xu, H. (1998). *Regional climate change in Portugal: precipitation variability associated with large-scale atmospheric circulation*. Int J Climatol 18: 619–635.
- Esteban-Parra, M.J.; Rodrigo, F.S. y Castro-Díez, Y. (1998). *Spatial and temporal patterns of precipitation in Spain for the period 1880-1992*. International Journal of Climatology, 18(14): 1557-1574.

- Field, A. (2005). *Discovering Statistics Using SPSS (Introducing Statistical Methods Second Edition.)*. Sage Publications.
- Gillett, N.P. y Fyfe, J.C. (2013). *Annular mode changes in the CMIP5 simulations*. Geophysical Research Letters, 40(6): 1189-1193.
- Haylock *et al.* (2008). *A European daily high-resolution gridded data set of surface temperature and precipitation for 1950-2006*. Journal of Geophysical Research-Atmospheres, 113 (20).
- Huang, N.E *et al.* (1998). *The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis*. Proceeding of the Royal Society of London Series a-Mathematical Physical and Engineering Sciences, 454 (1971): 903-995.
- Iglesias, A. y Quiroja, S. (2007). *Measuring the risk of climate variability to cereal production at five sites in Spain*. Clim Res 34:47-57.
- Kalnay E. *et al.* (1996). *The NCEP/NCAR 40-year reanalysis project*. Bulletin of the American Meteorological Society, 77(3): 437-471.
- Kucharik, C. y Serbin, S. (2008). *Impacts of recent climate change on Wisconsin corn and soybean yield trends*. Environmental Research Letters 3: 034003.
- Landau, S. *et al.* (1998). *Testing winter wheat simulation models' predictions against observed UK grain yields*. Agricultural and Forest Meteorology, 89, 85-99.
- Lobell, D. *et al.* (2008). *Prioritizing climate change adaptation needs for food security in 2030*. Science 319: 607-610.
- Martin, G.M. *et al.* (2011). *The HadGEM2 family of Met Office Unified Model climate configurations*. Geosci. Model Dev., 4, 723-757.
- Moreno, J.M. (2005). *A preliminary general assessment of the impacts in Spain due to the effects of climate change*. Ministerio del Medio Ambiente, Madrid.
- Rodo, X.; Baert, E. y Comin, F.A. (1997). *Variations in seasonal rainfall in southern Europe during the present century: Relationships with the North Atlantic Oscillation and the El Nino Southern Oscillation*. Climate Dynamics, 13(4): 275-284.
- Rodríguez-Puebla, C. *et al.* (2007). *Effects of climate variation on winter cereal production in Spain*. Clim Res. Vol. 34: 223-232, 2007
- Rosipal R. y Nicole Krämer N. (2006). *Overview and Recent Advances in Partial Least Squares*. Springer-Verlag Berlin Heidelberg, LNCS 3940, pp. 34-51.
- Smith, T.M. *et al.* (2008). *Historical reconstruction of monthly oceanic precipitation*. Journal of Geophysical Research-Atmospheres, 113 (D17).
- Song, Y.L.; Chen, D.L. y Dong, W.J. (2006). *Influence of climate on winter wheat productivity in different climate regions of China, 1961-2000*. Clim Res 32:219-227.
- Tao, F. *et al.* (2008). *Climate-crop yield relationships at provincial scales in China and the impacts of recent climate trends*. Climate Research 38: 83-94.
- Vicente-Serrano, S.M.; Cuadrat-Prats, J.M. y Romo, A. (2006). *Early prediction of crop production using drought indices at different time-scales and remote sensing data: application in the Ebro valley (North-East Spain)*. Int J Remote Sens 27:511-518.
- Vicente-Serrano, S.M. *et al.* (2014). *Evidence of increasing drought severity caused by temperature rise in southern Europe*. Environ. Res. Lett. 9 (2014) 044001 (9pp).
- Wold, S. *et al.* (2001). *PLS-regression: a basic tool of chemometrics*. Chemometrics and Intelligent Laboratory System, 58(2): 109-130.
- You, L. *et al.* (2009). *Impact of growing season temperature on wheat productivity in China*. Agricultural and Forest Meteorology 149: 1009-1014.
- Zhang, T. y Huang, Y.Z. (2012). *Impacts of climate change and inter-annual variability on cereal crops in China from 1980 to 2008*. Journal of Science of Food and Agriculture DOI: 10.1002/jsfa.5523.